

Rede Neural RBF aplicada ao Pré-Processamento de Sinais de Deformação em Estruturas de Alumínio

D. R. Louzada¹, C. Hall Barbosa², A. M. B. Braga¹, L.C.G.Valente¹, P.M.P. Gouvea¹ e D. F. Soria¹.

¹ Departamento de Engenharia Mecânica /PUC-Rio, Rio de Janeiro, Brasil

² Programa de Pós-Graduação em Metrologia /PUC-Rio, Rio de Janeiro, Brasil

daniel_louzada@hotmail.com, hall@ele.puc-rio.br, abraga@puc-rio.br, luizguedes@puc-rio.br, pgouvea@puc-rio.br,
dfalcon@hotmail.com

Resumo – As estruturas fabricadas pelo homem estão sujeitas aos efeitos do desgaste com o tempo, e sistematicamente necessitam de inspeções preventivas, a fim de se prevenir a ocorrência de danos, ou corretivas, para correção de determinado dano apresentado. Em diversas áreas de atuação, como na indústria, nos veículos (terrestres, aquáticos e aéreos) e em estruturas civis como pontes, edificações, ferrovias e túneis, a preocupação com o monitoramento da saúde estrutural (SHM – Structural Health Monitoring) tem sido constantemente estudada e discutida. Essa técnica procura implementar redes de sensores distribuídos ao longo da estrutura, de forma similar ao sistema nervoso humano, e dessa forma promover o monitoramento e gerenciamento da saúde, ou integridade estrutural, por meio das indicações dos sensores que respondem às mínimas mudanças decorrentes de alterações estruturais, como corrosão, fadiga ou delaminação, utilizando metodologias de inferência, como redes neurais artificiais (RNAs), garantindo assim maiores chances de se detectar e qualificar falhas estruturais, e até mesmo evitá-las. Uma das grandes vantagens dessa técnica reside no fato de se poder inspecionar a estrutura continuamente sem a necessidade de interromper o seu uso, contribuindo para uma maior eficiência tanto em segurança quanto em economia. O presente trabalho centra sua atenção na ocorrência de corrosão em painéis de alumínio, simulada numericamente por elementos finitos, abordando o tema com ênfase no pré-processamento inicial dos resultados das deformações superficiais, sob efeito de um carregamento estático. Tal processamento é realizado com o uso de redes neurais com funções de base radial (RBF), objetivando recuperar os perfis de deformação superficial a partir de um pequeno número de amostras. Dessa forma, realizando essa aproximação de função, deseja-se expandir a informação advinda de futuras medições com malhas de sensores, de modo a promover uma melhor avaliação das características do dano presente.

Keywords – Redes Neurais Artificiais (RNA), Funções de Base Radial (RBF – *Radial Basis Function*), Monitoramento da Saúde Estrutural (SHM – *Structural Health Monitoring*), Sensores a redes de Bragg (FBG – *Fiber Bragg Gratings*), Corrosão.

1 Introdução

O monitoramento estrutural é de grande importância na previsão, detecção e caracterização de corrosão em estruturas metálicas como dutos, pontes e aeronaves [1-3]. Sua implementação é de grande interesse industrial, uma vez que processos de corrosão são um dos eventos que mais afetam a integridade de estruturas, comprometendo o seu bom funcionamento. Estimam-se em milhões de Euros os gastos em manutenção e reparos, somente na indústria aeronáutica [4]. Kinzie e Peeler [5] sugeriram que novas formas de gerenciamento de corrosão em estruturas continuarão incentivando o desenvolvimento de testes, de ensaios não destrutivos, associados à integridade estrutural. A corrosão em painéis metálicos provoca uma perda de espessura do mesmo (nas regiões afetadas), o que altera a distribuição de tensões e, por conseguinte, a distribuição de deformações superficiais, as quais podem ser registradas por uma malha de sensores Strain Gages ou Redes de Bragg gravadas em fibras óticas (FBG – *Fiber Bragg Gratings*) [6]. O registro dessas alterações, associados com sistemas de RNAs, fornecem as ferramentas necessárias para um constante monitoramento dessas estruturas, permitindo que o problema inverso seja resolvido

(por meio das deformações obtidas, estimar a posição, tamanho e intensidade dos danos), e dessa forma viabilizando a implementação de manutenções pró-ativas em áreas específicas, reduzindo os custos.

Dentre as formas de sensoriamento, existem muitas classes de sensores que podem ser utilizados para fins de SHM, entretanto os sensores de fibra óptica têm se mostrado bastante eficientes e dessa forma ganhado espaço entre os pesquisadores da área [7]. Tal preferência se explica diante das características desses sensores, tais como, versatilidade para diferentes aplicações, robustez e estabilidade, insensibilidade à interferência eletromagnética, tamanho e peso reduzidos, segurança e grande poder de multiplexação e distribuição, ou seja, em uma mesma fibra podem ser colocadas vários sensores em diferentes posições (ou a fibra inteira funciona como um único sensor). Em especial, como o interesse é a obtenção de registros de deformação superficial das estruturas estudadas, os sensores de Rede de Bragg (FBGs) são fortemente recomendados.

Os FBGs são largamente utilizados por apresentarem boa sensibilidade e grande poder de multiplexação [8-9]. Uma das suas mais significantes vantagens advém do fato de que a informação referente ao sensor é codificada pelo comprimento de onda de Bragg. Dessa forma, como esse valor é absoluto, não existem influências nas flutuações decorrentes da fonte óptica ou decorrente de perdas ópticas na fibra. O princípio básico de operação de um sensor FBG consiste em se monitorar o desvio no comprimento de onda refletido pela rede de Bragg em função do que se está medindo. Isso ocorre por que o comprimento de onda de Bragg λ_B se relaciona com o índice de refração da fibra e o comprimento da rede de Bragg Λ através da equação 1.

$$\lambda_B = 2n\Lambda \quad (1)$$

O procedimento de medição se baseia na injeção de luz com banda espectral larga que, ao interagir com a rede de Bragg (presa à estrutura que se está monitorando), reflete parte da sua intensidade, com o comprimento de onda de Bragg. A análise da onda refletida, ou da onda transmitida, determina a deformação experimentada pela estrutura. A variação no sinal ocorre devido à distensão ou encurtamento da fibra quando submetida à tensão ou variação de temperatura (o que faz variar o valor de Λ). Esse efeito pode ser descrito pela equação 2, a seguir.

$$\Delta\lambda = k_\varepsilon\Delta\varepsilon + k_T\Delta T \quad (2)$$

onde k_ε é o coeficiente de sensibilidade à tensão, k_T é o coeficiente de sensibilidade à temperatura e $\Delta\lambda$ é a variação de comprimento de onda medida. Como a utilização de mais de uma rede de Bragg em uma mesma fibra (multiplexação) pode ser facilmente realizada, a utilização desses sensores abrem caminho para que haja a implementação de uma malha de sensores, distribuídos espacialmente em intervalos pré-determinados, que podem ser dispostos sobre a estrutura analisada, obtendo deformações em várias posições quase que instantaneamente. É importante salientar que a dependência desses sensores com a temperatura pode ser descontada com a utilização de mais um sensor FBG em uma região, que seja sabidamente imune às deformações experimentadas durante o monitoramento.

Tendo sido estabelecida a forma e a metodologia implementada no sensoriamento, o problema de SHM fica restrito ao processamento e interpretação dos dados obtidos. Nesse aspecto as técnicas de inteligência artificial são muito úteis, uma vez que possibilitam tratar questões não lineares, de difícil resolução analítica [10-13]. Com relação ao problema proposto neste trabalho, as redes neurais com função de base radial (RBF) são muito apropriadas no processamento dos dados por possuírem excelente capacidade de aproximar funções contínuas. Essa capacidade pode ser explorada de forma a se obter um número maior e mais exato de informações a respeito do comportamento mecânico (curvas de deformação da estrutura) quando submetidas a um determinado carregamento. Dessa forma, é possível trabalhar o problema de SHM com melhores informações (dados) do sistema mecânico, informações estas que só seriam possíveis de serem obtidos ou por simulações numéricas ou através de um número inviável de sensores atuando na estrutura sob investigação.

2 Modelagem do Problema

Foi modelada, com o auxílio de um programa de elementos finitos desenvolvido por meio do *softwear* ANSYS®, uma placa de alumínio com 400mm de comprimento, 130mm de largura e 3mm de espessura (Figura 1a). Outros parâmetros atribuídos à simulação deste modelo podem ser observados na tabela 1.

Tabela 1 – Parâmetros mecânicos utilizados no desenvolvimento da estrutura testada na simulação por elementos finitos.

Parâmetro	Símbolo	Valor
Comprimento	L_1	400 (mm)
Largura	L_2	130 (mm)
Espessura	L_3	3 (mm)
Modulo de Young	E	71,7 (GPa)
Coefficiente de Poisson	ν	0,33
Densidade	μ	2810 (kg/m ³)
Material	AL- 7075T6	-

Em cada simulação, a placa de alumínio se encontrava com um carregamento na forma de uma tração de 10MPa em uma das suas laterais (na direção do eixo x) enquanto a outra extremidade era mantida engastada, como mostra a figura 1b.

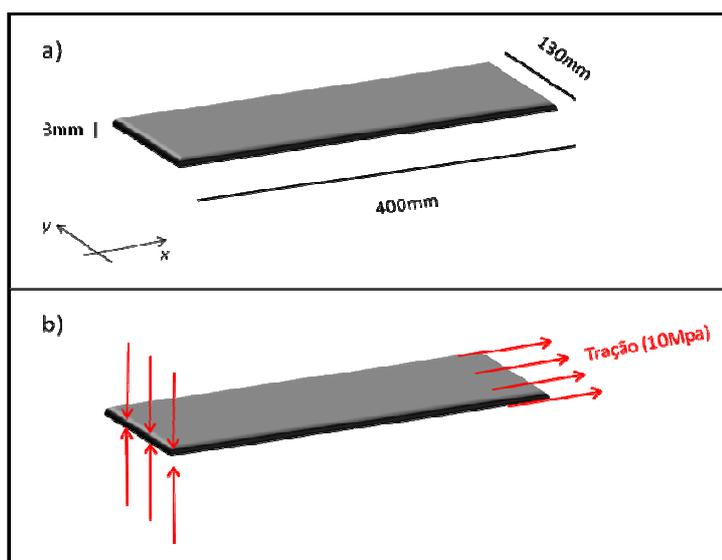


Figura 1 – Esquemático da estrutura de alumínio utilizada (a) e forma de carregamento imposto à mesma (b).

Sob estas condições iniciais de programação a simulação forneceu um mapa de deformações na superfície da placa. O passo seguinte consistiu em acrescentar ao modelo anterior uma região de desgaste (região com menor espessura), de forma a simular a presença de uma corrosão. A região de corrosão no modelo foi inserida no centro da placa, apresentando formato quadrangular. O programa foi parametrizado de tal forma a permitir que o tamanho do lado do quadrado de corrosão pudesse ser alterado assim como o tamanho do desgaste. Dessa forma, foi possível simular uma gama de situações abrangendo placas com corrosão de diferentes tamanhos e com diferentes intensidades (redução de espessura da placa).

Realizaram-se 48 simulações (além da simulação com a placa sem defeito algum), formando uma base de dados de deformação superficial de placas com efeitos quadrados de lado igual a 4 mm, 8 mm, 16 mm e 32 mm. Para cada um desses tamanhos de defeitos foi considerada uma variação na espessura do defeito da ordem de 5%, 10%, 15%, 20%, 25%, 30%, 35%, 40%, 45%, 50%, 55% e 60% da espessura inicial da placa. O período espacial de simulação dos dados foi 1 mm. Entretanto, como a aquisição de tal quantidade de informação por meio de ensaios experimentais seria inviável, os dados foram decimados de maneira que o período fosse igual a 17mm na direção x e 20 mm na direção y. Em outras palavras, um dado de deformação era coletado a cada 17 mm em relação ao eixo x da placa, e a cada 20 mm em relação ao eixo y. Essa situação é mais realística e

possível de ser reproduzida experimentalmente com uma rede de sensores. Para fins de simplificação do problema, uma vez que era conhecida a posição do defeito, optou-se por trabalhar somente com os dados de deformação provenientes de uma linha central, tanto horizontalmente (Linha Central em X) quanto verticalmente (Linha Central em Y), conforme Figura 2.

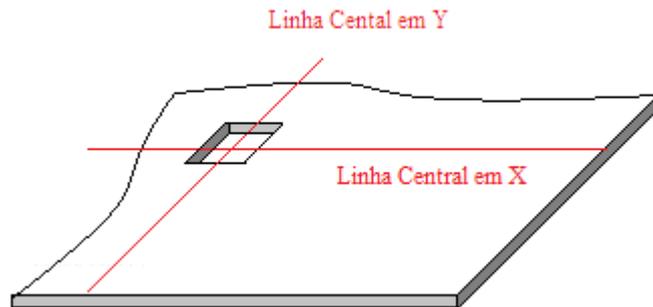


Figura 2 – Placa de Alumínio com perda de espessura localizada (corrosão) e linhas de dados demarcadas sobre o desenho.

Por fim, como um sensor não possui dimensões pontuais, e nem obtém informações de um ponto único no espaço, ao invés de se considerar os valores dos pontos equidistantes de 17 mm e 20 mm das linhas centrais, calculou-se a média aritmética destes com os pontos anterior e posterior aos mesmos.

3 Redes Neurais RBF

Uma rede neural RBF tem uma topologia básica com uma camada de entrada (variáveis de entrada do problema), uma camada de saída (resposta da rede neural) e uma camada escondida. Dessa forma as redes RBF são capazes de resolver problemas não linearmente separáveis. A principal diferença entre as redes RBF e as MLP (*Multi Layer Perceptron*) advém do fato de possuírem somente uma camada escondida e seus neurônios possuem função de ativação gaussiana [14]. Na figura 3 é mostrada a figura de uma curva gaussiana $f(x)$ com média m e desvio padrão σ .

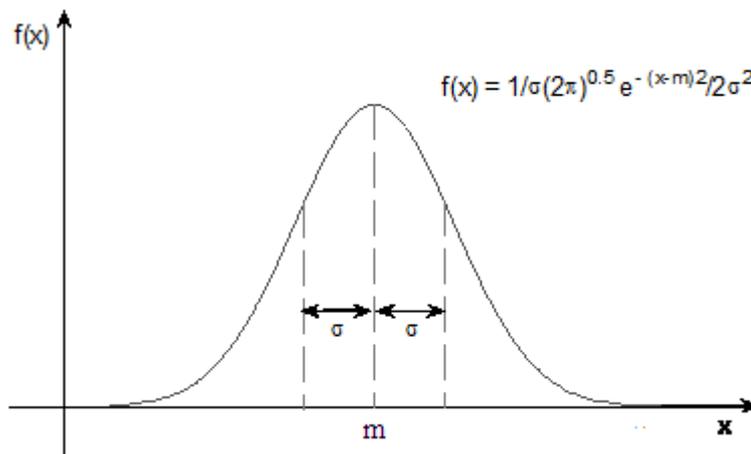


Figura 3 – Curva da função de ativação gaussiana de uma rede RBF.

Uma das principais características das RBFs é a ótima capacidade de aproximar qualquer função contínua por meio de uma combinação linear entre funções gaussianas, centradas em diferentes posições no espaço de entrada. A determinação da forma da gaussiana (definida pelo σ), a posição dos seus centros e o número de neurônios é o que define o quão aproximado irá ser o ajuste da função desejada.

O problema proposto por este trabalho consiste em trabalhar com os dados de deformação, obtidos pela simulação em elementos finitos, ajustando-os para uma situação próxima da possível de se obter experimentalmente, ou seja, da base de dados de 400 pontos de deformação referentes à linha central x e os 130 pontos referentes à linha central y, selecionar um número de 24 pontos para a linha x e 7 pontos para a linha y. Tal situação, apesar de representar, mais realisticamente, o que se pode conseguir em ensaios laboratoriais, representa uma dificuldade no que se refere à sua utilização como parâmetros de entrada para uma rede neural posterior, a fim de se obter alguma das características do defeito (problema inverso). Dessa forma

se torna necessário um pré-processamento desses dados, de forma que características essenciais do problema não sejam perdidas. No gráfico da figura 4, pode-se observar a perda de informação quando os dados são filtrados.

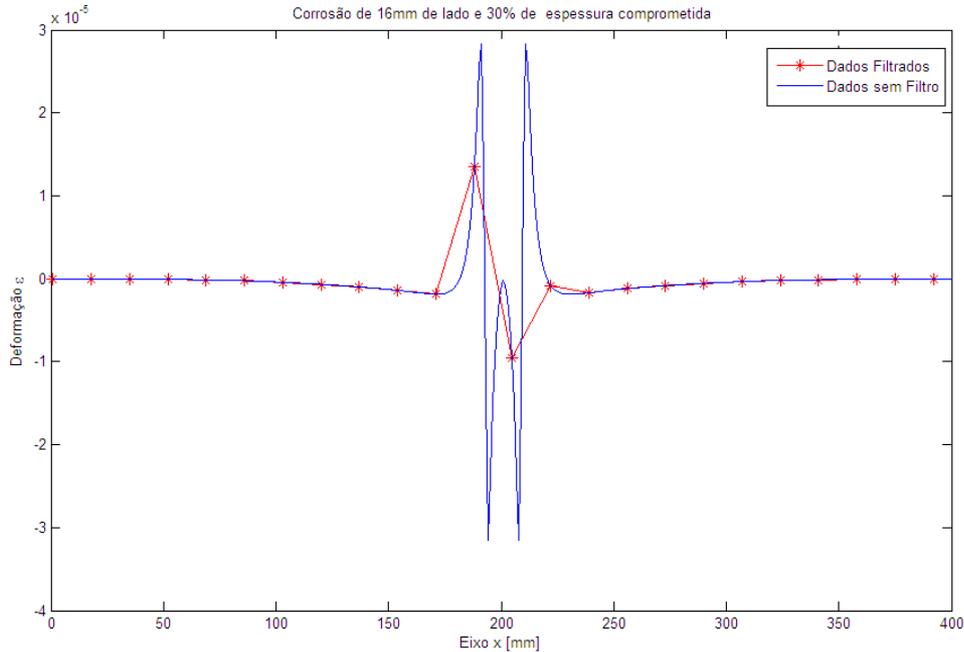


Figura 4 – Comparação entre curva obtida com os dados de deformação no eixo x antes da aplicação do filtro e com a aplicação do filtro.

A proposta então é utilizar redes RBF para obter as curvas de deformação, sem perda de informação, com base nos dados decimados. Um esquema de todo o procedimento proposto pode ser observado na figura 5.

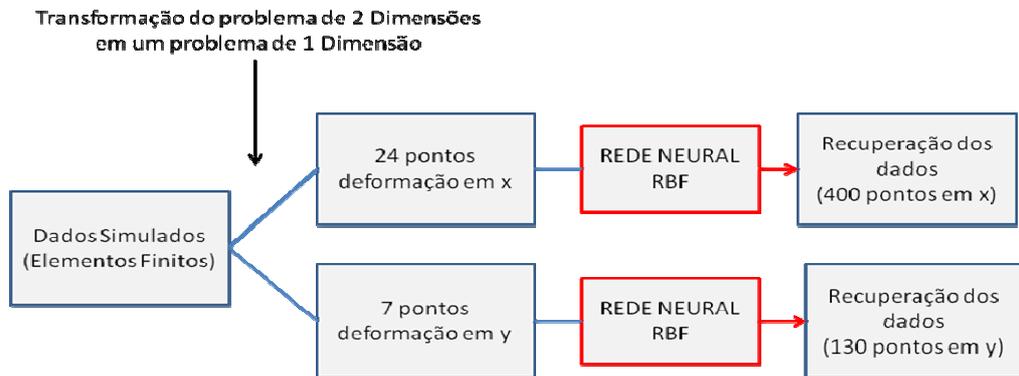


Figura 5 – Esquema do procedimento proposto para resolução do problema de perda de informações relevantes à resolução do problema inverso.

4 Resultados

Com base no que foi discutido, desenvolveram-se duas redes neurais RBF para recuperar os padrões de deformação superficial nas placas de alumínio. Os padrões de entrada para as RBFs foram divididos em 2 grupos de 48 padrões referentes à diferença de deformação registrada entre as situações com e sem defeito, sendo um grupo com os padrões referentes ao eixo x e outro grupo com os referentes ao eixo y. É importante frisar que em ambos os grupos de dados, só está se trabalhando com a componente x da deformação na placa. Destes 48 padrões, 80% foram fornecidos para a RBF ajustar seus pesos e os 20% restantes foram separados para testar a rede quanto a seu poder de generalização.

Inicialmente, pesquisou-se a melhor configuração das redes RBF, de acordo com os seus aspectos relevantes, ou seja, o número de neurônios da camada escondida e o desvio padrão σ . O gráfico da figura 6 exemplifica a relação entre o erro registrado com a comparação da saída da RBF, quando alimentadas com os dados de teste, e os dados obtidos pelas simulações em elementos finitos.

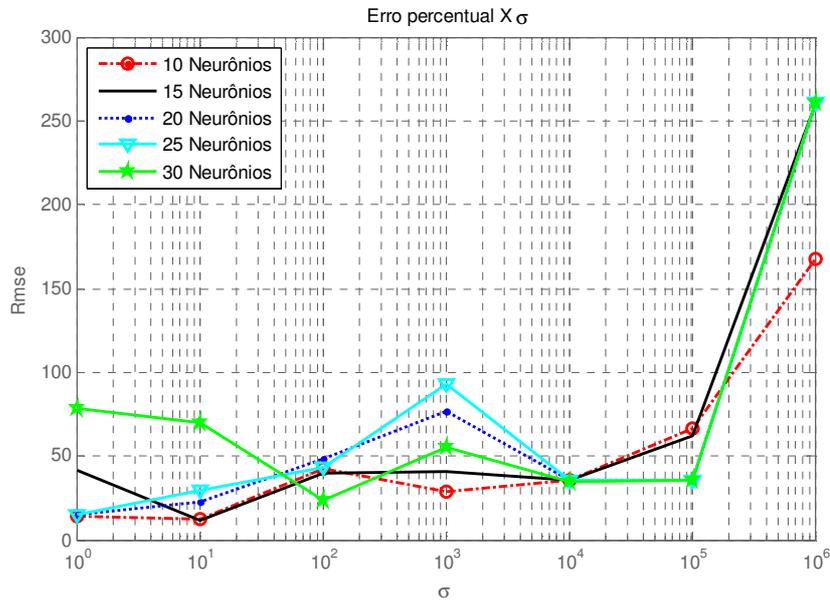


Figura 6 – Análise do erro obtido pela RBF em função do número de neurônios e σ .

Nos gráficos das figuras 7 e 8, um exame mais detalhado dessas regiões possibilitou a determinação da melhor configuração para as RBFs. As redes com 10, 15, 20 e 25 neurônios apresentam melhores resultados para valores de σ entre 0,1 e 12, de maneira que a configuração que apresentou menor erro foi a com 20 neurônios na camada escondida e um σ igual a 3.4.

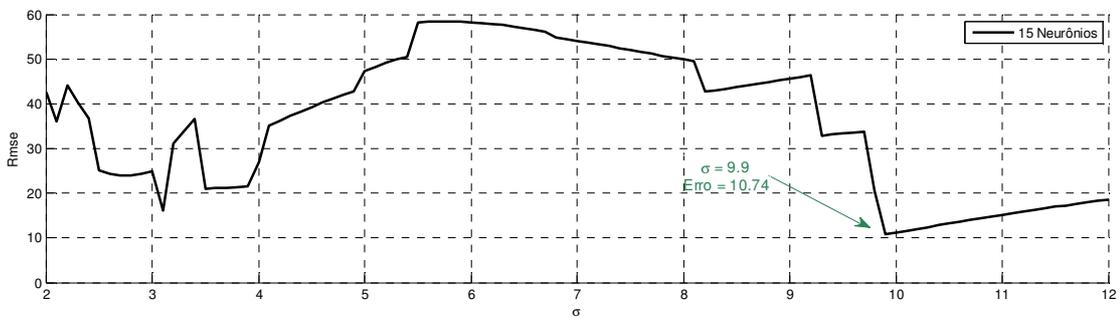


Figura 7 – Análise detalhada do erro obtido para 15 neurônios e σ variando de 0.1 a 12.

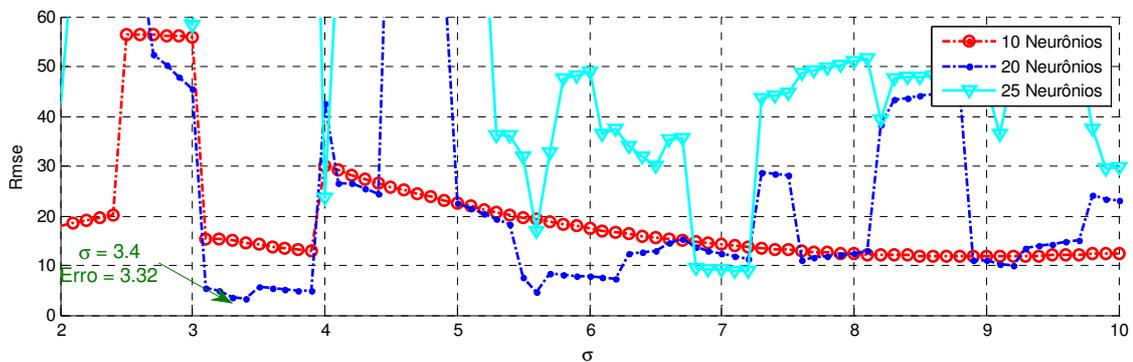


Figura 8 – Análise detalhada do erro obtido para 10, 20 e 25 neurônios e σ variando de 2 a 10.

O mesmo procedimento foi executado para se determinar as melhores configurações das RBF para os dados referentes à linha em y.

Com as Redes ajustadas para o menor erro, testou-se o seu funcionamento construindo gráficos sobrepostos dos resultados obtidos pela simulação em elementos finitos e os resultados de aproximação de função obtidos pelas RBF. Na figura 9 e 10 é possível observar tais curvas de deformação (linha central x e linha central y respectivamente) quando a corrosão era um quadrado de lado igual a 32mm e profundidade de 25% da espessura.

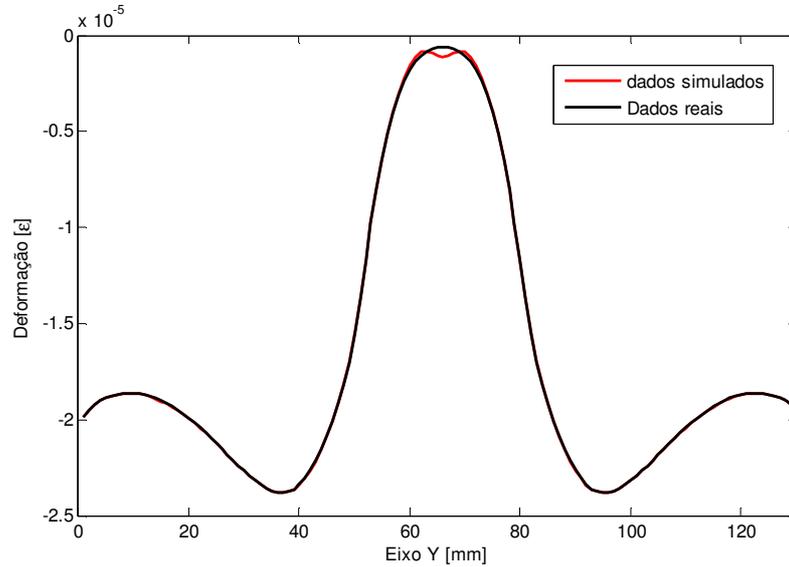


Figura 9 – Comparação entre os resultados obtidos por elementos finitos e pela RBF para um padrão de teste no eixo y.

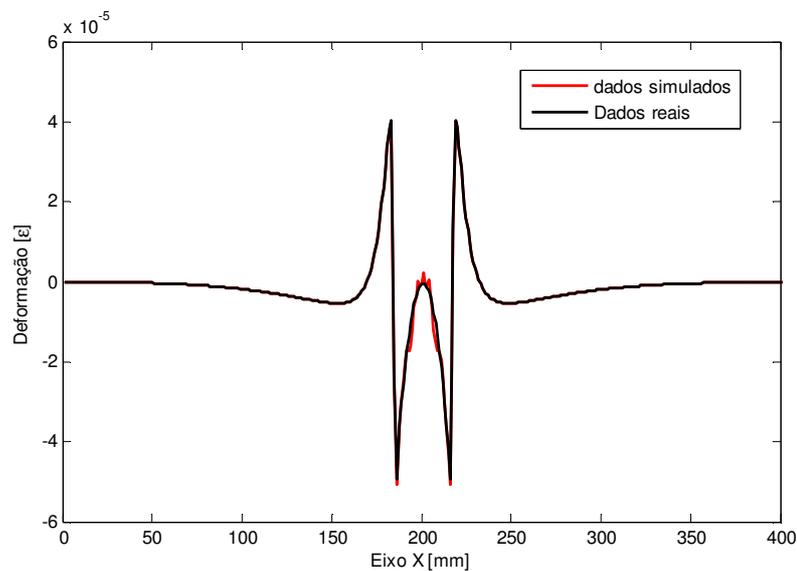


Figura 10 – Comparação entre os resultados obtidos por elementos finitos e pela RBF para um padrão de teste no eixo x.

5 Discussões e Conclusão

Resolver o problema inverso de modo a obter as características da corrosão em estruturas metálicas é uma das grandes preocupações atualmente. O potencial de implementar um sistema de SHM evitando a necessidade de se retirar o componente analisado do seu uso e ainda promover o aumento e melhoria da sua vida útil é, em termos financeiros, muito importante. No presente trabalho foi realizado um estudo a respeito dos procedimentos de sensoriamento em estruturas (em especial de alumínio), visando a atuar nos dados obtidos e recuperar as suas características gerais. Tais esforços se mostraram promissores

diante dos resultados positivos obtidos, abrindo caminho para estudos de casos onde os danos apresentam diferenças (entre situações com e sem dano) de sinais muito localizados.

Em uma etapa seguinte espera-se calibrar e obter as aproximações de funções das redes RBFs com dados medidos em situações reais de laboratório, para então propor um sistema SHM embarcado.

6 References

- [1] Park, C., Tang, J., Ding, Y. (2010). Aggressive data reduction for damage detection in structural health monitoring. *Structural Health Monitoring*, 9(1), 0059-16
- [2] Farrar C., Worden K.. (2007). An Introduction to Structural Health Monitoring. *Philosophical Transactions Royal Society A*, **365**, 303–315 doi:10.1098/rasta.2006.1928.
- [3] Farrar, C.R.; S.W. Doebling and D.A. Nix (2001). (2010). “Vibration- Based Strutral Damage Indentification”. *Philosophical Transactions of the Royal Society: Matematical, Physical & Engineering Sciences* **359** (1778): 131-149, doi:10.1098/rasta.2000.0717.
- [4] D. T. Peeler in Proceedings of 6th Joint FAA/DOD/NASA Aging Aircraft Conference, September, San Francisco, USA (2002).
- [5] Kinzie, R. and Peeler, D. (1999). Managing corrosion in the aging fleet: a new approach corrosion maintenance. 3rd FAA/DoD/NASA Aging Aircraft Conference, Albuquerque, New Mexico
- [6] Betz, D. C., Thursby, G., Culshaw, B. and Staszewski, W.J. (2007). Structural Damage Location with Fiber Bragg Grating Rosettes and Lamb Waves. *Structural Health Monitoring*, Vol 6(4): 0299–10.
- [7] Metje M., Chapman D.N., Rogers C.D.F., Henderson P., and Beth M. (2008). An Optical Fiber System for Remote Displacement Monitoring fo Structures – Prototype Testes in the Laboratory. *Structural Health Monitoring*, 7(1), 0051-13.
- [8] Friswell M.I. and Penny J.E.T. (2002). Crack Modeling for Strutral Helath Monitoring. *Structural Health Monitoring*, 1(21), 0139-148.
- [9] Krohn, D.A. (David A.). Fiber optic sensors: fundamentals and applications/ D.A. Krohn ed .Instrument Society of America, 3rd.
- [10] Soheil Saadat, Gregory D. Buckner, and Mohammad N. Noori. (2007). Structural System Identification and Damage Detection using the Intelligent Parameter Varying Technique Experimental Study. *Structural Health Monitoring*. Vol 6(3): 0231–13.
- [11] Ramana M. Pidaparti. (2007). Structural Corrosion Health Assessment using computational Intelligence Methods. *Structural Health Monitoring*. Vol 6(3): 0245–15
- [12] C. Antony Jeyasehar, and K. Sumangala. (2006). Nondestructive Evaluation of Pre Stressed Concrete Beams using an Artificial Neural Network (ANN) Approach *Structural Health Monitoring*. Vol 5(4): 0313–11
- [13] Pei Luo,* Dongsheng Zhang, Lixin Wang and Desheng Jiang Key Laboratory (2010). Neural Network: An Experimental Study Structural Damage Detection Based on a Fiber Bragg Grating Sensing Array and a Back Propagation *Structural Health Monitoring*. . Vol 9(1): 0005–7
- [14] Simon Haykin, Redes Neurais Princípios e Prática, Memillan Bookman, 2001.